

XVI ERIAC
DECIMOSEXTO ENCUENTRO
REGIONAL IBEROAMERICANO DE CIGRÉ

17 al 21 de mayo de 2015



A1-11

Comitê de Estudio A1 - Máquinas Eléctricas Rotativas

ESTRATÉGIA PARA SELEÇÃO DE SUB-BANDAS WAVELET EM SISTEMAS DE MONITORAMENTO DE DESCARGAS PARCIAIS

R. F. ZAMPOLO*
UFPA
Brasil

A. J. C. SENA
IESAM
Brasil

P. R. M. VILHENA
Eletrobrás/Eletronorte
Brasil

F. S. BRASIL
Eletrobrás/Eletronorte
Brasil

V. DMITRIEV
UFPA
Brasil

R. M. S. OLIVEIRA
UFPA
Brasil

Resumo *– Este artigo apresenta uma técnica para seleção de sub-bandas wavelet como etapa preliminar de um sistema de monitoramento e análise de descargas parciais. Tal seleção é realizada de maneira automática, mediante o uso de um classificador baseado em rede neural artificial do tipo SLFN (single hidden layer feedforward network) com algoritmo de aprendizagem ELM (extreme learning machine). O desempenho do classificador é avaliado para sinais simulados em diferentes condições de SNR (signal-to-noise ratio) e variações da frequência central do sinal de descargas parciais. Os resultados mostram que, tanto na fase de treinamento quanto na de teste, as taxas de classificação correta ficam acima de 92% a partir de 20 neurônios na camada oculta, aproximadamente. É apresentado ainda um exemplo de aplicação da técnica em sinais reais coletados em hidrogeradores em operação na usina de Coaracy Nunes (Amapá, Brasil).*

Palavras chave: *Seleção de sub-bandas wavelet, descargas parciais, hidrogeradores, single hidden layer feedforward network, extreme learning machine.*

1. INTRODUÇÃO

A qualidade da isolação em máquinas elétricas pode ser inferida mediante o monitoramento de suas descargas parciais (DPs). As técnicas usadas nesse sentido podem ser genericamente classificadas em offline e online. As técnicas online realizam o monitoramento e análise de DPs com a máquina em funcionamento em seu ambiente normal de operação. Todavia, tal abordagem exige que uma fase de processamento anteceda a análise dos sinais coletados, uma vez que o aparato de aquisição de sinais, nesse caso, está mais sujeito a ruídos e interferências [1, 2].

Diversos artigos [3, 4] têm demonstrado que as técnicas de redução de ruído baseadas em wavelets possuem desempenho melhor que as baseadas em filtragem convencional ou adaptativa. O procedimento padrão para redução de ruído por transformada wavelet consiste em utilizar limiares fixos ou adaptativos a partir dos quais os coeficientes nas diversas sub-bandas serão preservados, atenuados ou suprimidos, caso seus valores estejam acima ou abaixo dos referidos limiares [5–7].

Neste trabalho é proposta uma técnica para seleção das sub-bandas que melhor caracterizem um determinado sinal de DP. A premissa adotada é que o sinal de DP ocupa uma região relativamente estreita no domínio espectral, de modo que se possam descartar algumas sub-bandas wavelet sem que isso acarrete alterações importantes nos atributos de interesse, tais como, posição e valor de pico das DPs. Tal procedimento se

* Ronaldo de Freitas Zampolo. Universidade Federal do Pará, Instituto de Tecnologia, Faculdade de Engenharia da Computação e de Telecomunicações, Laboratório de Processamento de Sinais – Rua Augusto Corrêa, 01 – Guamá 66075-110. Belém – Pará – Brasil. Email: zampolo@ieee.org

justifica pois, a banda ocupada pelas DPs medidas pode sofrer alteração, por exemplo em decorrência do envelhecimento da isolação ou de variações de carga, resultando em mudanças no conjunto de sub-bandas importantes. Assim, a realização periódica desse procedimento de seleção é interessante para que o sistema de aquisição se adapte às eventuais mudanças espectrais.

A técnica proposta consiste em utilizar um classificador do tipo SLFN (single hidden layer feedforward network) com algoritmo de aprendizagem ELM (extreme learning machine) [8] para selecionar as sub-bandas mais relevantes em um determinado momento. Os valores médio, máximo e a variância da densidade espectral de potência (PSD, power spectrum density), estimados para cada coeficiente de detalhe de sub-banda wavelet, são utilizados como entrada do classificador, cuja saída informa quais as sub-bandas de maior importância. A base de conhecimento usada nas etapas de treinamento e teste do classificador é composta de DPs geradas artificialmente contaminadas com ruído do tipo Gaussiano branco aditivo (AWGN, additive white gaussian noise) para diversos valores de razão sinal-ruído (SNR, signal-to-noise ratio) e variação da posição central do espectro do sinal de DP.

Este trabalho está organizado como segue. Na Seção 2 é apresentado o modelo matemático adotado nas simulações deste artigo. Na Seção 3, a técnica proposta para seleção de sub-bandas wavelet é descrita em detalhes, compreendendo uma introdução ao classificador SLFN com algoritmo de aprendizagem ELM e o cálculo das features de entrada. O procedimento experimental e os resultados decorrentes são apresentados na Seção 4. A Seção 5 relaciona as conclusões do trabalho e na Seção 6 encontram-se as referências bibliográficas pertinentes.

2. MODELO MATEMÁTICO ADOTADO

O modelo matemático usado para representar o sinal adquirido $s(t)$, a partir do qual a análise de DP é realizada é dado a seguir.

$$s(t) = s_{\mathrm{dp}}(t) + s_{60\mathrm{Hz}}(t) + \eta(t) \quad (1)$$

onde t, $s_{\mathrm{dp}}(t)$, $s_{60\mathrm{Hz}}(t)$ e $\eta(t)$ representam a variável tempo, o sinal de DP, a senóide de 60 Hz e o ruído do tipo AWGN, respectivamente.

Dentre as possibilidades para modelar o sinal de descargas parciais, optou-se por um modelo simples que permite controlar suas características espectrais de largura de banda e frequência central, dado pela expressão

$$s_{\mathrm{dp}}(t) \ = \ \mathrm{sen}(2\pi f_c t + \theta)\left(e^{\frac{-t}{\lambda_2}} - \ e^{\frac{-t}{\lambda_1}}\right) \quad (2)$$

onde f_c, θ, λ_1 e λ_2 representam a frequência central, um parâmetro de fase aleatório, e as constantes de tempo 1 e 2 do modelo, respectivamente.

A fase θ possui distribuição uniforme no intervalo entre 0 e π. Por sua vez, o parâmetro f_c permite controlar a freqüência central da banda do sinal de DP, ao passo que as constantes λ_1 e λ_2 controlam sua largura de banda. Nas simulações deste trabalho, λ_1 e λ_2 foram deixados em valores fixos, sendo f_c variada com o objetivo de avaliar o desempenho da estratégia proposta (ver Seção 4).

3. SELEÇÃO DE SUB-BANDAS WAVELET

No contexto adotado neste trabalho, as sub-bandas wavelet de interesse, ou seja, aquelas que contêm uma parcela relevante da energia do sinal de DP, não são conhecidas *a priori*. Tal consideração se justifica em situações práticas quando as características espectrais dos sinais de DP não são conhecidas de antemão ou mesmo variam com o passar do tempo em função da variação de carga, envelhecimento do sistema de isolação ou surgimento de outras fontes de DP no equipamento monitorado. Nesse sentido, uma técnica de identificação para selecionar as melhores sub-bandas wavelet faz-se necessária. A técnica aqui descrita utiliza classificadores baseados em redes neurais em cuja camada de entrada são inseridos atributos (ou features) obtidos a partir da estimação da PSD dos coeficientes de detalhe das sub-bandas wavelet.

3.1 Atributos

A escolha de atributos baseados na PSD advém da consideração de que os sinais de descargas parciais ocupam uma faixa relativamente estreita do espectro se comparada com o ruído. Dessa forma, assume-se que há sub-bandas que podem ser desprezadas sem prejuízo na caracterização dos sinais de DP, ao mesmo tempo em que se elimina ruído e a componente de 60 Hz. Tal situação é ilustrada na Fig. 1 para sinais simulados em que a SNR é de 0 dB.

O procedimento para cálculo dos atributos consiste em primeiramente decompor o sinal ruidoso por um sistema de análise wavelet. Então, para cada coeficiente de detalhe do nível de decomposição i é estimada a respectiva PSD e, a partir desta, calcula-se sua média, variância e valor máximo. O coeficiente de aproximação do último nível de decomposição não é utilizado para o cálculo de features, pois porta sobretudo a informação do sinal de 60 Hz, irrelevante para caracterizar as DPs. A Fig. 2 ilustra o procedimento para um sistema de análise wavelet com k níveis de decomposição. Assim, o número de features a ser entregue para o classificador é igual a $3k$.

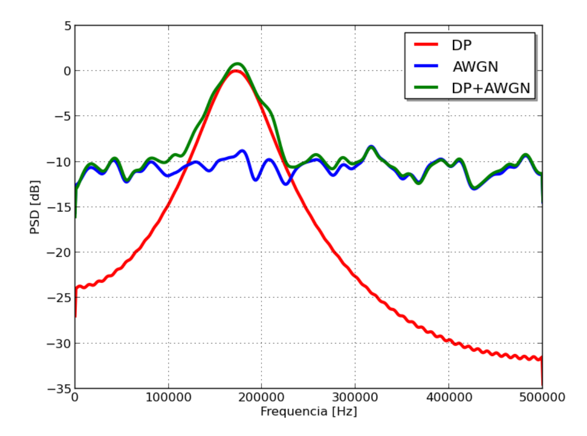


Fig. 1: Densidade espectral de potência normalizada de sinais simulados: descargas parciais (DP), ruído branco gaussiano (AWGN), e sinal completo (DP+AWGN).

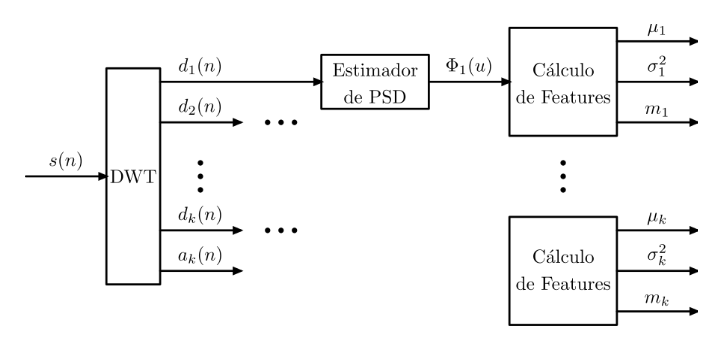


Fig. 2: Obtenção das features de entrada do classificador para seleção de sub-bandas importantes. DWT corresponde à transformada wavelet discreta (*discrete wavelet transform*); d_i e a_i representam os coeficientes de detalhe e aproximação da decomposição de nível i, respectivamente; Φ_i denota a estimativa da PSD dos coeficientes de detalhe d_i; μ_i, σ_i^2 e m_i são, respectivamente a média, variância e valor máximo de Φ_i.

As Figuras 3 a 5 exibem exemplos do comportamento da média, variância e valor máximo, respectivamente, da PSD dos coeficientes de detalhe das sub-bandas wavelet de sinais simulados para SNR de 0 dB (os valores apresentados nos gráficos estão normalizados). Pode-se observar que os atributos escolhidos preservam suas características principais entre a situação em que apenas os sinais de DP estão presentes e a situação na qual as DPs estão somadas a ruído AWGN (DP+AWGN), sugerindo, dessa forma, serem adequados para identificar as sub-bandas de interesse no segundo caso.

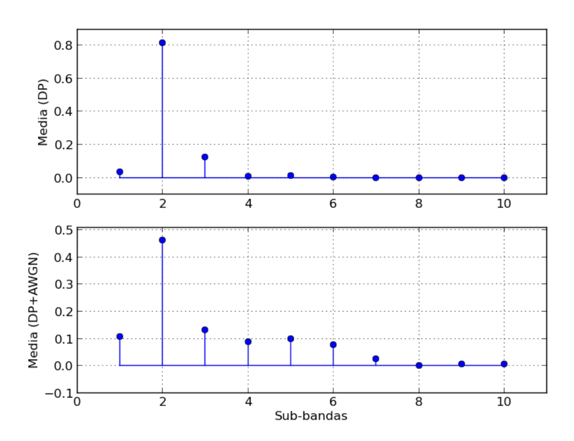


Fig. 3: Média da PSD dos coeficientes de detalhe das sub-bandas wavelet dos sinais de DP, e DP com ruído (DP+AWGN). O valor de SNR é de 0 dB.

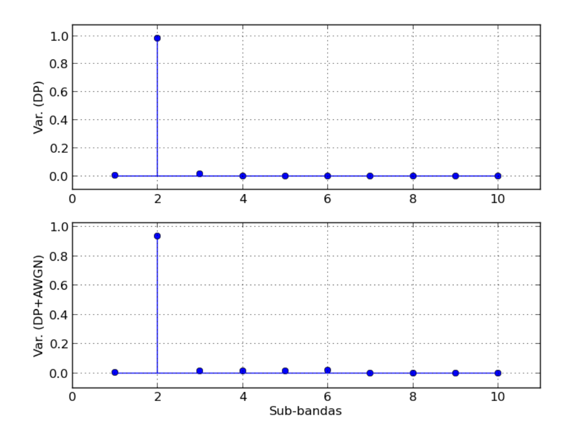


Fig. 4: Variância da PSD dos coeficientes de detalhe das sub-bandas wavelet dos sinais de DP, e DP com ruído (DP+AWGN). O valor de SNR é de 0 dB.

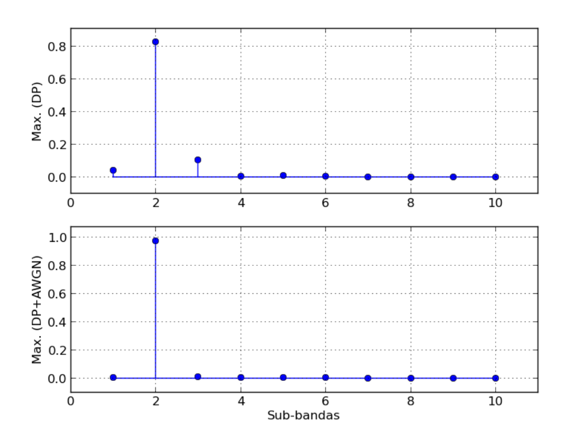


Fig. 5: Valor máximo da PSD dos coeficientes de detalhe das sub-bandas wavelet dos sinais de DP, e DP com ruído (DP+AWGN). O valor de SNR é de 0 dB.

3.2 Classificador SLFN com aprendizagem via ELM (SLFN-ELM)

Em situações em que a SNR possui valores elevados, a determinação de sub-bandas relevantes pode ser realizada até mesmo por inspeção visual dos três atributos mencionados na seção anterior. Contudo, à medida que os níveis de ruído aumentam, tal determinação torna-se mais difícil e uma estratégia automática mostra-se necessária.

Neste trabalho, foi usado um classificador baseado em redes neurais artificiais de uma única camada oculta com algoritmo de aprendizagem ELM. A adoção do ELM ao invés de uma abordagem convencional para ajuste dos pesos e *bias* da SLFN tem por objetivo reduzir a complexidade computacional da etapa de aprendizagem. Tal diminuição de complexidade é obtida considerando os pesos da camada de entrada e o vetor de *bias* como aleatórios, o que faz com que o processo de aprendizagem se reduza a determinar os pesos da camada oculta a partir da resolução de um sistema de equações lineares, desde que as funções de ativação na camada oculta sejam infinitamente diferenciáveis. A desvantagem associada é o fato de que a solução obtida é sub-ótima, sendo, contudo, satisfatoriamente próxima da solução ótima [8].

4. RESULTADOS EXPERIMENTAIS

4.1 Procedimento experimental

O procedimento experimental adotado para avaliação de desempenho do sistema proposto de seleção de sub-bandas importantes inicia com a geração dos sinais de DPs, segundo o modelo apresentado na Seção 2 e de maneira que se tenham exemplos com diferentes frequências centrais (Tabela I). Em seguida, as DPs foram contaminadas por ruído do tipo AWGN com variância ajustada para resultar nas SNRs apresentadas na Tabela II. Para cada par formado por frequência central e SNR foram gerados 100 exemplos, totalizando 8400 sinais de 1×10^6 amostras cada para serem usados nas etapas de teste e treinamento do classificador SLFN. Para cada um dos 8400 sinais foram anotadas as sub-bandas mais relevantes, de modo que a energia do erro entre a DP original e sua versão reconstruída a partir dos coeficientes de detalhes das referidas sub-bandas não fosse superior a 10% em relação à energia do sinal de DP original. Outros parâmetros de interesse à reprodutibilidade do experimento são apresentados na Tabela III. Na fase de treinamento da rede, foram utilizados 90% dos sinais gerados, escolhidos de maneira aleatória. Os 10% restantes foram usados na etapa de teste. Para cada realização treinamento/teste foi variado o número de neurônios da camada oculta de maneira a avaliar o comportamento do classificador em função da arquitetura da rede.

TABELA I. VALORES DE FREQUÊNCIA CENTRAL f_c USADOS (EM HZ)

$\boldsymbol{f_1}$	$\boldsymbol{f_2}$	$\boldsymbol{f_3}$	$\boldsymbol{f_4}$	$\boldsymbol{f_5}$	$\boldsymbol{f_6}$	$\boldsymbol{f_7}$	$\boldsymbol{f_8}$	$\boldsymbol{f_9}$	$\boldsymbol{f_{10}}$	$\boldsymbol{f_{11}}$	$\boldsymbol{f_{12}}$
$\mathbf{3.750 \times 10^5}$	1.875×10^5	9.375×10^4	4.687×10^4	2.343×10^4	1.171×10^4	5.859×10^3	2.929×10^3	1.464×10^3	7.324×10^2	3.662×10^2	1.831×10^2

TABELA II. VALORES DA RAZÃO SINAL-RUÍDO (SNR) USADOS NA SIMULAÇÃO

SNR (dB)
$\mathbf{40}$
$\mathbf{20}$
$\mathbf{10}$
$\mathbf{5}$
$\mathbf{0}$
$\mathbf{-5}$
$\mathbf{-10}$

TABELA III. OUTROS PARÂMETROS USADOS NAS SIMULAÇÕES

Descrição	**Valor**
Constante de tempo $\boldsymbol{\lambda_1}$	0.5×10^{-5} s
Constante de tempo $\boldsymbol{\lambda_2}$	$(1 + 1 \times 10^{-5})\lambda_1$ s
Frequência de amostragem	1×10^{6} Hz
Tipo de wavelet	Daubechies 7
Número de amostras por sinal	1×10^{6} amostras
Níveis de decomposição wavelet	10 níveis
Função de ativação da SLFN	Sigmóide

4.2 Resultados obtidos

Os resultados apresentados a seguir encontram-se divididos em avaliação de desempenho do classificador nas etapas de treinamento e teste (Seção 4.2.1), e um exemplo usando a estratégia de seleção automática de sub-bandas wavelet aplicada à filtragem de um sinal real coletado em um dos hidrogeradores da usina de Coaracy Nunes (Seção 4.2.2).

4.2.1 Resultados obtidos por simulação

A Fig. 6 mostra as taxas de acerto (classificação correta) do classificador SLNF-ELM em função do número de neurônios da camada oculta nas etapas de treinamento e teste. Pode-se observar que o desempenho do classificador varia significativamente para arquiteturas com número de neurônios da camada oculta abaixo de 20, aproximadamente. Depois disso, as taxas de acerto sofrem pequena mudança, não justificando, assim, o aumento de complexidade computacional advinda do acréscimo de elementos na camada oculta. É importante notar a taxa de acerto acima de 92% obtida na identificação das sub-bandas relevantes, tanto na fase de treinamento quanto na fase de testes.

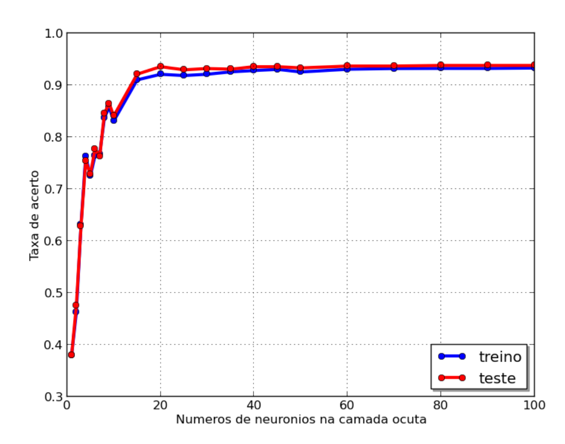


Fig. 6: Taxas de acerto do classificador SLFN-ELM na determinação de sub-bandas wavelet importantes em função do número de neurônios da camada oculta.

4.2.2 Exemplo de utilização em sinais reais

A seguir, a título de exemplo, são apresentadas ilustrações de um sistema de monitoramento e análise de descargas parciais (SIM-DP, sistema de medição de descargas parciais) que utiliza, ainda em caráter experimental, a estratégia proposta neste trabalho como etapa preliminar para redução de ruído usando filtragem wavelet. Os sinais foram coletados de um hidrogerador da usina hidroelétrica de Coaracy Nunes (Amapá, Brasil).

Na Fig. 7, é mostrado um gráfico contendo o sinal coletado em que se nota claramente as descargas parciais sobrepostas à senóide de 60Hz. Na Fig. 8, tem-se a interface do usuário para seleção de sub-bandas, que pode ser feita manualmente ou de maneira automática usando o classificador SLFN-ELM previamente treinado. E na Fig. 9, é mostrado um trecho do sinal de descargas parciais obtido por filtragem wavelet considerando as sub-bandas escolhidas anteriormente pelo classificador.

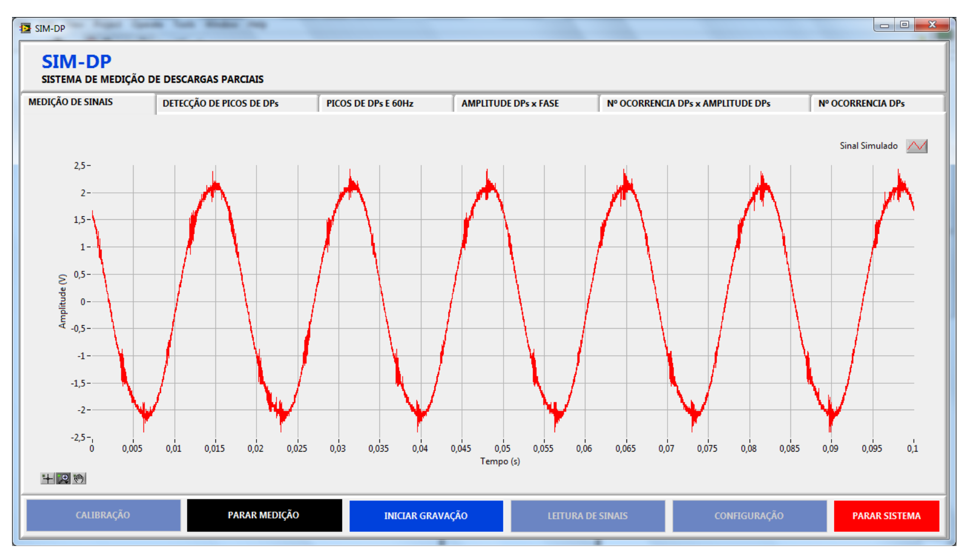


Fig. 7: Trecho de sinal coletado de um hidrogerador da usina hidroelétrica de Coaracy Nunes (Amapá, Brasil) e exibido pelo SIM-DP.

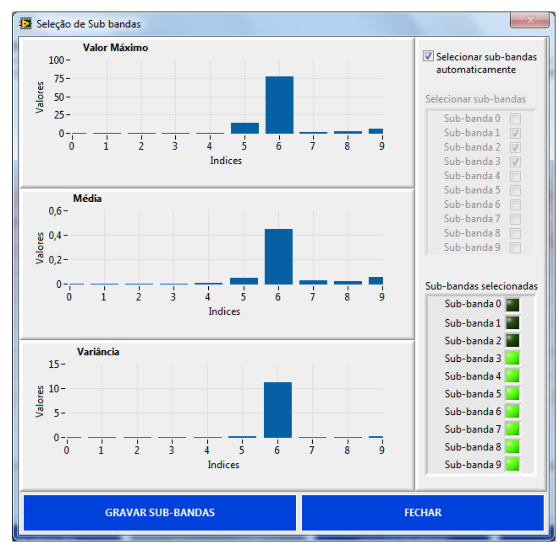


Fig. 8: Subsistema do SIM-DP que implementa a estratégia proposta para seleção de sub-bandas wavelets importantes.

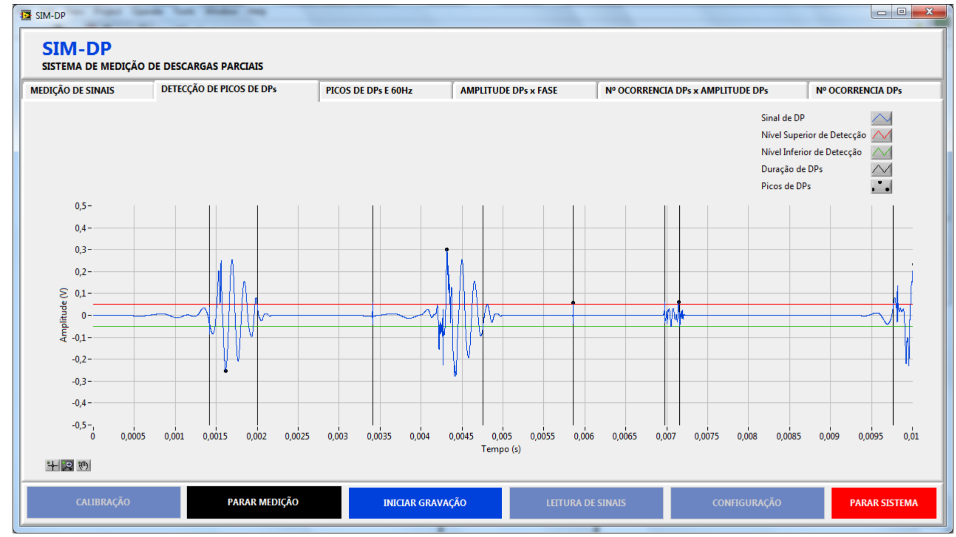


Fig. 9: Sinal de descargas parciais obtido mediante filtragem wavelet a partir das sub-bandas selecionadas pelo classificador SLFN-ELM proposto.

5. CONCLUSÕES

Neste artigo foi apresentada uma estratégia para seleção automática de um conjunto de sub-bandas wavelet que melhor represente um sinal de descargas parciais. Tal estratégia consiste em usar um classificador baseado em redes neurais artificiais do tipo SLFN com algoritmo de aprendizagem ELM. Os atributos de entrada do classificador são a média, a variância e o valor máximo da PSD de cada um dos coeficientes de detalhe do sinal a ser analisado, modelado como sendo o sinal de descargas parciais, somado a ruído do tipo ANWG e à senóide de 60 Hz. Resultados de simulação mostraram que o classificador obteve taxas de acerto acima de 92% a partir, aproximadamente, de 20 neurônios na camada oculta, tanto na fase de treinamento quanto na de teste, sugerindo um bom potencial para aplicação prática da técnica.

Os próximos passos relacionados à continuidade do trabalho compreendem: a realização de testes comparativos adicionais com outros tipos de wavelet; avaliar em maiores detalhes como o desempenho do classificador se comporta em função da SNR, da frequência central e da largura de banda do sinal de descargas parciais; o emprego de outros modelos matemáticos para representar sinais adquiridos, principalmente no que diz respeito à presença de outras fontes de interferência, tais como sinais de rádio frequência e chaveamento de componentes eletrônicos.

6. REFERÊNCIAS

[1] **Bartnikas, R.** Partial discharges. Their mechanism, detection and measurement. *Dielectrics and Electrical Insulation, IEEE Transactions on.* Outubro de 2002, Vol. 9, 5, pp. 763-808.

[2] **Stone, G. C.** Partial discharge diagnostics and electrical equipment insulation condition assessment. *Dielectrics and Electrical Insulation, IEEE Transactions on.* Outubro de 2005, Vol. 12, 5, pp. 891-904.

[3] **Mota, Hilton de Oliveira, et al.** Partial discharge signal denoising with spatially adaptive wavelet thresholding and support vector machines. *Electric Power Systems Research.* Fevereiro de 2011, Vol. 81, 2, pp. 644-659.

[4] **Sriram, S., et al.** Signal denoising techniques for partial discharge measurements. *Dielectrics and Electrical Insulation, IEEE Transactions on.* Dezembro de 2005, Vol. 12, 6, pp. 1182-1191.

[5] **Vidya, H. A., et al.** Removal of Interferences from Partial Discharge Pulses using Wavelet Transform. *TELKOMNIKA.* Abril de 2011, Vol. 9, 1, pp. 107-114.

[6] **Mallat, Stéphanne.** *A Wavelet Tour of Signal Processing: The Sparse Way.* Terceira edição. s.l. : Academic Press, 2008.

[7] *Partial discharge signal denoising using wavelet techniques-on site measurements.* **Sharmila, G., Maheswari, R. V. e Subburaj, P.** 2013. Circuits, Power and Computing Technologies (ICCPCT), 2013 International Conference on. pp. 673-678.

[8] **Huang, Guang-Bin, Zhu, Qin-Yu e Siew, Chee-Kheong.** Extreme learning machine: theory and applications. *Neurocomputing.* Dezembro de 2006, Vol. 70, 1-3, pp. 489-501.